

Sveučilište u Zagrebu
Prirodoslovno – matematički fakultet
Biološki odsjek

Željka Drdar

Usporedba metoda za mjerenje raspoložive svjetlosti u prizemnom sloju šumske vegetacije

Diplomski rad

Zagreb, 2011. godina

Ovaj rad, izrađen u Botaničkom zavodu, pod vodstvom doc. dr. sc. Sven Jelaska, predan je na ocjenu Biološkom odsjeku Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu radi stjecanja zvanja magistar Ekologije i zaštite prirode.

Zahvaljujem se mentoru doc. dr. sc. Svenu Jelaski na stručnom vodstvu i pomoći bez kojih izvedba ovog rada ne bi bila moguća.

Isto tako zahvaljujem kolegama Igoru Dolenjaku i Margariti Miletić koji su sudjelovali i pomogli mi pri obavljanju terenskog djela istraživanja, te Margariti još jednom na ustupljenim fotografijama s terena.

Zahvaljujem svojim roditeljima na podršci, ljubavi i strpljenju koje su mi pružali tijekom cijelog studija.

Velika hvala i svim prijateljima, s fakulteta i iz BIUS-a, na podršci, hrabrenju, savjetima, zapitkivanjima i predivnom prijateljstvu kojima su me obasipali svih ovih godina.

I za kraj, hvala i svim ostalim prijateljima i poznanicima koji su mi bili društvo, oslonac i podrška bez kojih ne bih uspjela.

TEMELJNA DOKUMENTACIJSKA KARTICA

Sveučilište u Zagrebu

Prirodoslovno-matematički fakultet

Biološki odsjek

Diplomski rad

Usporedba metoda za mjerenje raspoložive svjetlosti u prizemnom sloju šumske vegetacije

Željka Drdar

Rooseveltov trg 6, Zagreb

Istraživanje je provedeno na području Parka prirode Medvednica na šest različitih šumskih ploha kako bi se utvrdile sličnosti i razlike između triju metoda za mjerenje svjetlosti u prizemnom sloju šumske vegetacije. Također je testirano koliko je podataka svake metode potrebno uzeti po istraživanoj plohi da bi se dobili slični rezultati. Ispitivane metode su bile mjerenje svjetlosti svjetlomjerom, hemisfernom fotografijom te priručnom metodom. Na svakoj od ploha određeno je devet točaka u pravilnoj 3x3 mreži na kojima su uzimani podaci za navedene metode. Podaci su obrađeni te je pet njihovih kombinacija provedeno kroz statističku analizu. Pokazalo se da unutar metoda ne postoje značajne razlike na razini ploha za priručnu metodu i hemisfernu fotografiju, ali razlike su postojale kod metode svjetlomjera na razini cijelog uzorka što bi se objašnjava iznimnom osjetljivošću instrumenta na okolišne uvjete. Ustanovljena je slaba korelacija između priručne metode i ostalih metoda, što se objašnjava drugačijim principom rada te mogućim neiskustvom ispitivača.

Rad sadrži 40 stranica, 25 slika, 8 tablica, 62 literaturna navoda, jezik izvornika : hrvatski.

Rad je pohranjen u Središnjoj biološkoj knjižnici.

Ključne riječi: šumska krošnja, svjetlost, Medvednica, svjetlomjer, hemisferna fotografija

Voditelj: Dr. sc. Sven D. Jelaska, doc.

Ocjenitelji: Dr. sc. Sven D. Jelaska, doc.

Dr. sc. Jasna Hrenović, izv. prof

Dr. sc. Ivančica Ternjej, prof.

Rad prihvaćen: 09.09.2011.

BASIC DOCUMENTATION CARD

University of Zagreb

Faculty of Science

Department of Biology

Graduation Thesis

A comparison of methods for estimating available understory light in forests

Željka Drdar

Rooseveltov trg 6, Zagreb

The research was conducted in Medvednica Nature Park upon six different forest plots, with aim to determine conformabilities and differences between three methods for estimating understory light in forest vegetation. An additional test was made to determine the quantity of each method data, per disquisitional plot, required to obtain similar results. The examined methods were light estimating by light meter, hemispherical photography and manual technique. Each plot was divided in nine locations, arranged in 3x3 grid, upon which data was collected. Data was processed and than five combinations have been statisticly analysed. Results have shown that there were no significant differences for manual technique and hemispherical photography within plots. The differences were showed for light meter which is explained by high sensitivity of the instrument. Low corelation between manual technique and other two methods was shown, which is explained by different measuring system of examined methods and possible inexperience of observer.

Thesis contains 40 pages, 25 pictures, 8 tables, 62 references, original in : Croatian.

Thesis deposited in Central biological library.

Key words: forest canopy, light, Medvednica, light meter, hemispherical photography

Supervisor: Dr. sc. Sven D. Jelaska, Asst. Prof.

Reviewers: Dr. sc. Sven D. Jelaska, Asst. Prof.

Dr. sc. Jasna Hrenović, Assoc. Prof.

Dr. sc. Ivančica Ternjej, Prof.

Thesis accepted: 09.09.2011.


Sadržaj:

1. Uvod	1
1.1. Značaj svjetla kao abiotičkog čimbenika	1
1.2. Mjerenje raspoloživog svjetla	3
1.2.1. Razlozi i prednosti mjerenja raspoloživog svjetla	3
1.2.2. Metode mjerenja raspoloživog svjetla	4
1.3. Ciljevi istraživanja	8
2. Materijal i metode	9
2.1. Područje istraživanja	9
2.2. Opis šumskih tipova (ploha)	12
2.3. Terensko uzorkovanje	16
2.3.1. Postavljanje mjerne mreže.....	16
2.3.2. Sklop krošnji mjeren pomoću hemisferne fotografije	16
2.3.3. Sklop krošnji mjeren svjetlomjerom	19
2.3.4. Sklop krošnji mjeren priručnom metodom	20
2.4. Obrada podataka	21
2.4.1. Analiza podataka dobivenih trima metodama za mjerenje svjetlosti	21
2.4.2. Analiza linearne koreliranosti za parove metoda	23
2.4.3. Testiranje razlika srednjih vrijednosti triju metoda za mjerenje svjetlosti Friedman ANOVA sumom rangova	23
3. Rezultati	24
3.1. Podaci dobiveni mjerenjem svjetlosti i rezultati njihove analize	24
3.2. Rezultati linearne koreliranosti za parove metoda	29
3.3. Rezultati testiranja razlika srednjih vrijednosti triju metoda za mjerenje svjetlosti Friedman ANOVA sumom rangova	30
4. Rasprava	31
5. Zaključci	34
6. Literatura	35

1. Uvod

1.1. Značaj svjetla kao abiotičkog čimbenika

Život na Zemlji danas uvelike ovisi o Sunčevoj energiji. Osim topline, Sunce je izvor još jednog ekološkog faktora, a to je Sunčeva svjetlost, vrsta elektromagnetske energije (zračenja, radijacije) koja se kreće kroz prostor u obliku elektromagnetskih valova različitih valnih duljina. Ipak, samo jedan mali dio cijelog spektra valnih duljina, vidljiva svjetlost (oko 400 nm – 700 nm valne duljine) (Slika 1.) odgovoran je za jedan od ključnih procesa u prirodi – fotosintezu. Direktno ili indirektno, svi organizmi ovise o ovom kemijskom procesu koji godišnje proizvede oko 160 milijardi tona ugljikohidrata (nikakav drugi kemijski proces ne može proizvesti količinu niti približnu ovoj) te tako predstavlja izvor hrane za gotovo sav živi svijet (Bašić-Zaninović i Perić 2004).



Slika 1. Elektromagnetski spaktar zračenja i raspon vidljive svjetlosti (Preuzeto od: [http://www.fot-o-grafiti.hr/nauci/svjetlo-i-rasvjetu/svjetlost-sto-je-to](http://www.fotografiti.hr/nauci/svjetlo-i-rasvjetu/svjetlost-sto-je-to); pristupljeno 6.8.2011.)

Zelene biljke kao skupina organizama uvelike doprinose životu na Zemlji putem procesa fotosinteze za koji je svjetlost ključan čimbenik, ali isto tako u velikoj mjeri i ovise o svjetlosti kao atmosferskom ekološkom abiotičkom faktoru koji im je prijeko potreban za život. Iako ima manje značenje za geografsko rasprostranjivanje biljaka nego temperatura, svjetlo bitno utječe na pojavu vegetacije na pojedinim užim područjima iste geografske zone, tj. u različito osvijetljenim zajednicama i ekosustavima iste geografske zone značajano doprinosi formiranju strukturnih svojstava biljaka, njihovoj morfologiji, rastu, razvoju te opstanku na određenim staništima (Gračanin i Ilijanić 1977).

O važnosti svjetla za biljke govori već i sama činjenica kako su ovi organizmi razvili cijeli spektar prilagodbi i oblika kako bi zadovoljili svoje potrebe za ovim ekološkim čimbenikom. Kao posebne oblike biljaka koji su se razvili u kompeticiji za svjetlošću treba izdvojiti povijuše i penjačice (lijane), zakorijenjene u tlu, koje se svojim tankim stabljikama penju po drugim biljkama, stijenama i zidovima te na taj način dovode lišće najkraćim putem iz sjene i s tla prema Sunčevoj svjetlosti, a pritom same ne razvijaju jaka nosiva stabla, te epifite koji se nastanjuju na stablima i granama krošnji gdje su i ukorijenjeni te na taj način osiguravaju povoljnije mjesto s obzirom na Sunčevu svjetlost. Svjetlost također može biti uzrokom posebnih prilagodbi u biljaka, poput svjetlosnih zakrivljavanja (fototropizama), slobodnih lokomotornih gibanja kojima upravlja svjetlost (fototaksija) i promjena oblika koje su izazvane svjetlošću (fotomorfogeneza), a koje se odvijaju unutar područja vidljive svjetlosti (koje se zbog toga može nazvati i područjem fotobiologije) (Strasburger i sur. 1988). Uglavnom, pomoću biokemije i fiziologije biljke odgovaraju na okolišne uvjete u obliku svoje anatomije i morfologije i o tome ovisi njihova funkcionalna ekologija (npr. biljka tako može razviti dvije vrste listova: pri vrhu krošnje gdje je velika izloženost sunčevoj radijaciji, razvit će se sitniji i deblji listovi, a pri dnu krošnje, u sjeni, listovi veće površine koji su tanji, što će biljci pomoći da na kvalitetniji način iskoristi dostupno svjetlo) (Gurevitch i sur. 2002). Neke biljke su se morale prilagoditi uvjetima smanjene količine svjetla, pa se takvu sposobnost biljaka da rastu i razvijaju se u zasjenjenim staništima naziva tolerancijom. Ono drveće koje je netolerantno razvija otvorene krošnje tankog lišća kako bi više svjetla moglo prodrijeti kroz krošnju do površine šumskog tla, što omogućuje uspješnije nicanje njihovih mladih klica (Gračanin i Ilijanić 1977).

Isto tako, u šumama se često formiraju katovi vegetacije, ovisno o količini dostupne svjetlosti koja kroz sklop krošnji dopire do prizemnog sloja u šumi. Kod otvorenog sklopa krošnji, s tankim lišćem, mnogo svjetlosti prodire kroz krošnju te dolazi do površine šumskog tla gdje se formiraju niži slojevi vegetacije. Tako se u rijetkoj šumi razvijaju različite razine vegetacije: visoko grmlje, nisko grmlje, visoko zeljasto bilje, nisko zeljasto bilje, mahovine, lišajevi i gljive. Kada je sklop šume zatvoren, ovi katovi nestaju (Gračanin i Ilijanić 1977). Isto tako, ako se usred šume sruši veliko stablo (čija je krošnja do tada na tom mjestu radila sjenu), pojavit će se novo stanište s većom količinom svjetlosti i unutar te mikroklimе će se početi formirati vegetacija kojoj pogoduju novostvoreni uvjeti. Dokazano je kako otvorenost/zatvorenost sklopa krošnje značajno može utjecati na rast i preživljavanje mladica nekih vrsta biljaka (Chacón i sur. 2005). Struktura krošnje tako ima presudnu ulogu u kontroliranju količine, kvalitete, prostorne i vremenske distribucije svjetla, te također može

utjecati na lokalnu količinu oborina i kretanje zraka, a time i na vlažnost zraka, temperaturu te u određenom stupnju i na vlagu tla na svakom mjestu unutar šume (Jennings i sur. 1999). Utjecaj strukture krošnje na količinu raspoloživog svjetla u prizemnom sloju šumske vegetacije i vlažnost šumskog tla pokazali su Lin i sur. (1992).

1.2. Mjerenje raspoloživog svjetla

1.2.1. Razlozi i prednosti mjerenja raspoloživog svjetla

Najjednostavniji način utvrđivanja tolerancije vegetacije na svjetlost jest mjerenje intenziteta svjetla u šumskom prizemnom sloju, što se može provesti na različite načine. Mjerenjem intenziteta svjetla u prizemnom sloju šuma može se ustanoviti o kakvom se tipu krošnje radi, kakvi svjetlosni ekološki uvjeti na tom području vladaju te kako to utječe na pojavu određene vegetacije na tom području i proces sukcesije, a ovakva istraživanja se osim u šumama mogu provoditi i na drugačijim staništima, primjerice u šikarama (Dickinson i sur. 1993). Čak i male promjene u osvjetljenosti mogu imati značajan utjecaj na rast i preživljavanje biljaka u staništima gdje je smanjena količina dostupnog fotosintetski aktivnog zračenja (vidljiva svjetlost).

U današnje vrijeme kada se stavlja naglasak na prirodnu regeneraciju šuma i pošumljavanje ekosustava koji su bili degradirani kao posljedica djelovanja čovjeka ili prirodnih katastrofa, poznavanje ekoloških uvjeta (između ostalog i svjetlosnih) koji utječu na rast vegetacije u prizemnim slojevima (uključujući i klijance, mladice i subdominantno drveće) je od velike važnosti (Brown i sur. 2000). Metode za mjerenje svjetla u prizemnom sloju šuma i procjene šumskog pokrova mogu se koristiti za praćenje prirodnih procesa u različitim šumskim ekosustavima (Payton 1988, Ostertag 1998, Souza i Martins 2005, Mihók i sur. 2007), te fizioloških procesa u samim biljkama kao što su količina dnevno adsorbirane sunčeve radijacije i fotosinteze u krošnjama te relativne brzine rasta (Klassen i sur. 2003). Moguće je praćenje zdravstvenog stanja šuma i uočavanje promjena na šumskom pokrovu koje mogu biti uzrokovane raznim štetnicima (Dottavio 1981), prirodnim nepogodama poput uragana (Grove i sur. 2000, Comita i sur. 2009) i požara (McCarthy i Robison 2003, Stephens i sur. 2006), ali i šumskim radovima, tj. siječom stabala (Beaudet i Messier 2002, Asner i sur. 2004). Nadasve su korisne u monitoringu stanja staništa koja su bila izložena degradaciji i fragmentaciji (Hadi i sur. 2004), a rezultati dobiveni njihovom primjenom mogu poslužiti u planiranju upravljanja održivim ekosustavima i zaštićenim područjima (Prasad i sur. 2008,

Tan i sur. 2010). Podaci nekih metoda, poput mjerenja indeksa gustoće šume (Engl. Stand Density Index, SDI), mogu se koristiti u predviđanju daljnjeg razvoja zatvorenosti krošnji pomoću posebnih modela (Haywood i sur. 1995). Može se promatrati utjecaj zasjenjenosti na produktivnost šumskog tla, ali i pašnjaka kao što su radili Knowles i sur. (1999) te Devkota i sur. (2001) na Novom Zelandu. Isto tako može se promatrati utjecaj zatvorenosti i gustoće šumskog pokrova na ostala živa bića, primjerice na vrijeme njihova izlaženja iz skrovišta u večernjim satima što su kod šišmiša vrste *Barbastella barbastellus* potvrdili Russo i sur. (2007) ili na abundanciju i raznolikost herbivornih kukaca (Basset i sur. 2001).

1.2.2. Metode mjerenja raspoloživog svjetla


Sunčevo zračenje nakon ulaska u atmosferu može biti različito, ovisno o uvjetima kroz koje zrake Sunčeve svjetlosti prolaze na svom putu do površine Zemlje. Međudjelovanjem s plinovima i česticama u atmosferi Sunčevo zračenje se može upiti (apsorpcija), odbiti (refleksija) ili može manje ili više nesmetano proći kroz atmosferu (transmisija). Na površini Zemlje možemo mjeriti izravno (direktno) Sunčevo zračenje, raspršeno (difuzno) Sunčevo zračenje i ukupno (direktno i difuzno) Sunčevo zračenje. Ovisno o vrsti, postoje različite metode mjerenja Sunčevog zračenja, tj. svjetlosti.

Sunčevo zračenje mjerimo nekim od klasičnih instrumenata, primjerice, izravno (direktno) Sunčevo zračenje mjeri se pirheliometrom. Ukupno sunčevo zračenje (direktno i difuzno zajedno) se mjeri piranometrom, a raspršeno (difuzno) Sunčevo zračenje se može mijeriti piranometrom ako se Sunčev disk zasjeni tako da do instrumenta ne može doći izravno Sunčevo zračenje.

No, mjerenje sunčeva zračenja u prizemnom sloju šuma može biti zahtjevno zbog uvjeta koji u takvom staništu prevladavaju. Kako se radi o relativno promjenjivom ekosustavu kojim se gospodari i koji se i sam razvija, sastav šumskog svoda se neprestano mjenja u prostoru i vremenu. Kvaliteta i kvantiteta osvjetljenosti tu su heterogene i dobiveni podaci su trenutni. Zbog prostorne varijabilnosti potrebno je uzeti puno mjera u relativno kratkom vremenu kako bi utjecaj promjena vremenskih prilika koje prevladavaju na području istraživanja na rezultate bio što manji. Metode bi trebale biti jednostavne za korištenje, ponovljive i što preciznije.

Potrebno je spomenuti kako se mjerenje količine svjetla u prizemnom sloju u šumi često provodi mjerenjem sklopa šumske krošnje i to na dva načina. Prvi je način mjerenje zatvorenosti krošnje (Engl. Canopy closure) koja je definirana kao udio nebeske hemisfere

koji je zaklonjen vegetacijom kada se promatra iz jedne točke (pojam dijametralno suprotan ovom je otvorenost krošnje). U šumarskoj literaturi se kao sinonim za ovaj pojam često navodi i gustoća krošnje (Engl. Canopy density). Drugi način je mjerenje šumskog pokrova (Engl. Canopy cover), a odnosi se na udio šumskog tla koji je prekriven vertikalnom projekcijom šumskih krošanja. Dakle, mjerenja zatvorenosti krošnji ujedanjuju informacije o segmentu nebeske hemisfere gledano s jedne točke iznad površine tla, a mjerenja šumskog pokrova procjenjuju prisutnost ili odsunost krošnje vertikalno iznad nekoliko točaka na šumskoj površini (Slika 2.) (Jennings i sur. 1999). Moglo bi se reći da sam se na terenu prilikom ovog istraživanja bavila procjenom zatvorenosti krošnje mjereći količinu svjetla i sklop krošnji gledajući ih s jedne točke, ali također i šumskog pokrova s obzirom da sam na svakoj od odabranih ploha u šumi uzimala podatke s ukupno devet točaka.



Slika 2. Primjer mjerenja zatvorenosti krošnje (a) i šumskog pokrova (b) (Preuzeto od: Jennings i sur. 1999)

Najčešće korištene metode za mjerenje raspoloživog svjetla u prizemnom sloju šuma su (1) hemisferna fotografija sklopa krošnji i (2) istovremena usporedba raspoloživog svjetla pod šumskom „draperijom“ i na otvorenom prostoru s više senzora (tzv. svjetlomjeri), o kojima ću više reći u poglavlju koje se bavi opisom materijala i metoda.

Osim ovih postoji i mnoštvo drugih metoda kojima se mjeri količina svjetlosti u prizemnom sloju šuma, poput omjera crvene i daleko crvene (Engl. ratio of red to far-red light – R:FR) svjetlosti (Capers i Chazdon 2003). Za mjerenje zatvorenosti krošnji mogu se koristiti i različiti uređaji za mjerenje stupnja optičke gustoće (tame), tzv. sferni densiometri, a razlikuju se konkavni i konveksni, ovisno o tome koju vrstu zrcala koriste (Korhonen i sur. 2006, Mihók i sur. 2007). Poznata i često korištena metoda je i mjerenje indeksa lisne površine (Engl. Leaf Area Index, LAI) koja se može provoditi direktnim uzorkovanjem ili indirektno pomoću analiza različitih snimki (He i sur. 2007), a u crnogoričnim šumama

moguće je mjeriti i gustoću, raspored i orijentaciju iglica na mladicama drveća (Stenberg i sur. 1999). Moguće je mjerenje gustoće toka fotona fotosinteze (Engl. Photosynthetic photon flux density, PPFD) što se pokazalo korisnim za brze procjene strukture šumske krošnje (Machado 1999, Lindner 2011). Relaskop je instrument koji se primarno koristi u šumarstvu za mjerenje dimenzija stabala, a za mjerenje površine krošnje prilagodili su ga Stenberg i sur. (2008). U slučaju da nema puno vremena za terenski rad, statistički modeli su se dokazali kao prikladna zamjena za procjenu zatvorenosti šumske krošnje, ali pod uvjetom da su za izradu samog modela korišteni prijašnji podaci s dotičnog područja istraživanja (Korhonen i sur. 2007, Zeng i sur. 2008). U istu svrhu su razvijeni i razni računalni programi koji kombiniraju podatke prikupljene na terenu s 3D modelima krošnji kako bi se dobila procjena otvorenosti krošnji (Silbernagel i Moeur 2001).

Postoje i različite priručne metode za mjerenje količine svjetlosti i zatvorenosti šumskih krošnji koje se mogu napraviti po principu «uradi sam». Poput cijevi u koju može biti ugrađena žica u obliku križa kroz koju se gleda vertikalno uvis na određenim postajama na odabranoj plohi u šumi i potom bilježi je li «nišan» na određenoj točki pogodio krošnju ili otvor u krošnji šume (Ganey i Block 1994). U Finskoj, instrument sličan ovome nazivaju i Cajanovom cijevi (Engl. Cajanus tube) koja je ondje jedna od najpoznatijih terenskih metoda za mjerenje zatvorenosti sklopa krošnji na tradicionalan i učinkovit način (Rautiainen i sur. 2005, Korhonen i sur. 2006). Brown i sur. (2000) osmislili su metodu elipsa rasvjetljenosti krošnje (Engl. Crown illumination ellipses) gdje se veličina otvora u krošnji procjenjuje uspoređujući ih s nizom elipsi otisnutih na prozirnoj perspektivnoj pločici. Slična ovoj je metoda procjene otvorenosti krošnje pomoću instrumenta naziva *moosehorn* (naziv inače potječe od sličnosti s instrumentom koji služi za lov na losove) (Brown i sur. 2000, Fiala i sur. 2006), a koji će u nešto izmjenjenom obliku koristiti u ovom istraživanju.

Okularne (očne) procjene šumskih krošnji su moguće ukoliko drugi alati za procjenu nisu dostupni, ali ih mogu provoditi samo iskusne osobe, a zbog subjektivnosti koja se u procjenama ne može izbjeći često se smatraju nepouzdanima (Korhonen i sur. 2006). Jedna takva metoda gdje se krošnje na temelju opažanja svrstava u određene razrede naziva se indeksom rasvjetljenosti krošnje (Engl. Crown illumination index) (Brown i sur. 2000).

Zahvaljujući napretku znanosti, danas se sve češće u svrhu procjena gustoće šumskog pokrova primjenjuju metode tzv. daljinskog promatranja (Engl. Remote Sensing, RS) kojima se mogu dobiti informacije o osobinama (fizičkim, kemijskim i biološkim) objekata bez fizičkog kontakta, a provode se snimanjem dijelova površine Zemlje iz aviona ili satelita različitim senzorima. Ovakve metode uključuju analizu satelitskih snimki šumskih područja,

što se pokazalo korisnim u procjeni gustoće šumskog pokrova na velikom području, temelji se na uočavanju četiri pokazatelja (tlo, sjene, toplina i vegetacija), bez puno izlazaka na terene, a u vremenu i s troškovima koji su prihvatljivi (Azizi i sur. 2008, Sasaki i sur. 2008). Mogu se raditi usporedbe snimki različitih vegetacija i vidjeti utjecaji zatvorenosti krošnji i drugih okolišnih faktora na dostupnost sunčeve svjetlosti (Dottavio 1981). Istraživanja se mogu provoditi korištenjem nekoliko različitih tipova podataka koji su dobiveni iz različitih vrsta senzora te se potom vrši njihova usporedba (Gong i sur. 1994, Xu i sur. 2003) ili se za snimke dobivene pomoću jednog senzora mogu koristiti različiti modeli obrade (Pu i sur. 2003). Moguće je iz podataka dobivenih satelitskim snimanjem zaključivati o karakteristikama snimane vegetacije (poput visine drveća i širine stabla) (Oladi 2001), a došlo se i do zaključka da je zbog specifičnosti staništa potrebno prilagoditi vrstu senzora koji će biti korišten u istraživanju (Lobell i sur. 2001). Osim iz zraka, sastav šumskog pokrova može se snimati, tj. skenirati i s tla pomoću lasera čime se dobiva 3D prikaz gustoće biljnih elemenata (lišća, stabljika, grana i dr.) (Van der Zande i sur. 2010). Moguće su i usporedbe podataka dobivenih laserskim snimanjem (i s tla i iz zraka) s onima koji su dobiveni na terenu nekom od tradicionalnijih metoda (Korhonen i sur. 2010).

1.3. Ciljevi istraživanja


Kako je mjerenje svjetla u prizemnom sloju šumske vegetacije na terenu delikatan posao jer na rezultate može utjecati cijeli niz okolišnih faktora, a često u istraživanjima nije moguće koristiti više metoda koje bi se potom uspoređivale, potrebno je znati pouzdanost metoda te njihove prednosti i mane.

Glavni je cilj istraživanja stoga ustanoviti koliko se razlikuju metode mjerenja raspoloživog svjetla u prizemnom sloju šumske vegetacije, a na temelju rezultata zaključiti mogu li se iste koristiti zasebno kao pouzdani alati za dobivanje kvalitetnih podataka i rezultata. Polazna je hipoteza da ne bi trebale postojati značajne razlike između istraživanih metoda za mjerenje svjetlosti. U istraživanju sam provela usporedbu triju metoda: jedne indirektne (hemisferna fotografija), jedne direktne (svjetlomjera) i jedne priručne. Dodatni cilj je testirati koliko je mjerenja svake metode po plohi šumske vegetacije dovoljno za postizanje sličnih rezultata.

2. Materijal i metode

2.1. Područje istraživanja

Istraživanje sam provela u južnom i središnjem dijelu Parka prirode Medvednica koji obuhvaća područje planine Medvednice smještene između 15° 49' 45" i 16° 07' 45" geografske dužine i 45° 49' 00" i 45° 59' 00" geografske širine (Nikolić i Kovačić 2008). Park zauzima površinu od 22 826 ha, proteže se područjem čak tri županije (Grada Zagreba, Zagrebačke županije te Krapinsko-zagorske županije), a proglašen je 16.6.1981. godine (Nikolić i Kovačić 2008). Godine 2009. granice Parka su pomaknute čime je smanjena njegova površina (Slika 3.), ali površina unutar starih granica Parka ulazi u tzv. «Botanički važna područja» (Engl. Important Plant Areas, IPA) (Vuković i Nikolić 2010). Unutar Parka postoje i manja područja površine 997 ha koja su posebno zaštićena kao botanički rezervati i rezervati šumske vegetacije (Nikolić i Kovačić 2008).



Slika 3. Stare i nove granice Parka prirode Medvednica

Sam masiv Medvednice smješten je sjeverno od Zagreba i pruža se u smjeru jugozapad-sjeveroistok u duljini od 42 km, dok mu je najviši vrh, Sljeme, visok 1035 m. Građen je od stijena koje starošću datiraju od razdoblja paleozoika do kvartara, a po postanku pripadaju svim trima osnovnim tipovima (magnetske, sedimentne i metamorfne). Mnoštvo brdskih izvora i potoka koji većinom izviru iznad 750 m n. v. na propusnim podlogama tvore

krške oblike poput ponikvi, na rasjedima gdje na površinu izbija voda zagrijana u dubini Zemlje nastaju topli izvori, a vodotoci se koriste za opskrbu lokalnog stanovništva pitkom vodom. U odnosu na grad Zagreb, Medvednica ima malo oštriju klimu jer je temperatura zraka kroz cijelu godinu nešto niža. Godišnja količina oborina je za oko 50% veća, a ima i oko 100 sati više sunčanog vremena, najčešće u zimskom periodu (Nikolić i Kovačić 2008).

Područje je najvećim dijelom prekriveno šumskim pokrovom koji je dobro očuvan, a zauzima površinu od 14 550 ha (64% ukupne površine Parka) dok ostatak otpada na travnjake, voćnjake, vinograde, ratarske kulture i različite građevine (Nikolić i Kovačić 2008).

Kako se radi o brdsko-planinskom području, pod utjecajem nadmorske visine i ekspozicije dolazi do smjene (zoniranja) šumskih tipova. U najnižim dijelovima do oko 250 m n. v. pojavljuje se zajednica hrasta kitnjaka i običnoga graba (As. *Epimedio-Carpinetum betuli* /Horvat 1938/ Borhidi 1963), a u istoj zoni na kiselim tlima dolaze acidofilni tipovi kitnjakovih šuma (Sveze *Quercion robori-petraeae* Br.-Bl. 1932 i *Castaneo-Quercion petraeae* /Soó 1962/ Vukelić 1990) koji mogu dosegnuti i 750 m n. v. Najveći dio Medvednice prekrivaju različiti tipovi bukovih šuma, od kojih je najrašireniji pojas mezofilnih i neutrofilnih čistih bukovih šuma (As. *Lamio orvale-Fagetum sylvaticae* Ht. 1938) koje zauzimaju čak 33,28% staništa unutar IPA Medvednice (Vuković i Nikolić 2010), a dolaze u rasponu od 300 do 820 m n. v. Unutar ove zone na mjestima gdje je tlo teško i osiromašeno zbog ispiranja dolazi tip acidofilne bukove šume s bjelkastom bekicom (As. *Luzulo-Fagetum sylvaticae* Meusel 1937). U vršnoj zoni od 800 do 1000 m n. v. dolazi mješana zajednica bukovo-jelove šume (As. *Festuco drymeiae-Abietetum* Vukelić et Baričević 2007) koja se na sjevernim padinama Medvednice spušta i do 400 m n. v. (Nikolić i Kovačić 2008, Vuković i Nikolić 2010).

Osim gore navedenih, u manjoj količini zastupljene su i mnoge druge šumske zajednice koje su se razvile uslijed specifičnih ekoloških uvijeta, npr. šuma crne johe s drhtavim šašem (As. *Carici brizoides-Alnetum glutinosae* Horvat 1938) koja dolazi u dolinama potoka koje se često poplavljuju, dok se u pojasu bukove šume na sjenovitim i strmim padinama sa sjeverne strane masiva može naići na fragmentirano stanište mješovite šume tise i lipe (As. *Tilio-Taxetum* Glavač 1958) (Vuković i Nikolić 2010).

U Parku se osim šumskih javljaju i nešumske zajednice te staništa nastala antropogenim utjecajem poput botanički vrijednih travnjaka (na kojima rastu mnoge vrste orhideja), krčevina, uzgojnih kultura (mozaici kultiviranih površina zauzimaju čak 13,68% staništa unutar IPA Medvednice), vrtova, povrtnjaka i različita mikrostaništa poput izvorišta,

obala potoka, golih kamenih blokova i stijena, ulaza u speleološke objekte, i sl. (Vuković i Nikolić 2010).


Inače, flora Medvednice bilježi 1205 vrsta i podvrsta (oko 22% ukupne nacionalne flore koja dolazi na svega 0,4% državnog teritorija koliko zauzima Park) što kazuje o značajnoj i nadasve zanimljivoj bioraznolikosti koja se nalazi nadomak velikog urbanog područja. Tako se osim široko rasprostranjenih (kozmpolitskih) vrsta, na Medvednici mogu naći i euroazijske, cirkumholarktičke, europske, atlantske i sredozemne (na staništima koja su toplija i okrenuta jugu) vrste te također i terciarni relikti zaostali iz perioda ledenih doba. Među njima je 268 biljnih vrsta koje su zaštićene zakonom (a od njih je strogo zaštićeno čak 115) te 14 vrsta hrvatskih endema (Nikolić i Kovačić 2008).

Zbog činjenice da se nalazi u neposrednoj blizini glavnoga grada, Medvednicu tijekom cijele godine posjećuje veliki broj ljudi što značajno utječe na ovo područje te ima brojne posljedice koje se mogu očitovati na staništu i negativno utjecati po bioraznolikost. Napravljene procjene upotrebe zemljišta ukazuju na visok intenzitet šumarenja i turizma/rekreacije, djelatnosti koje inače mogu biti korisne, ali ako ih se ne nadzire mogu ostaviti ozbiljne posljedice po okoliš, a osim njih zemljište se također koristi i u poljoprivredne i lovne svrhe. Jaki antropogeni utjecaj na zaštićeno područje zbog blizine grada stvara pritisak na okoliš, a najčešći uzroci ugroženosti su: gradnja prometnica, širenje rubnih dijelova grada, razvoj turizma/rekreacije (npr. širenje skijališta), šumarstvo (sječa), širenje alohtonih biljnih vrsta (od kojih su neke invazivne), skupljanje autohtonih vrsta (npr. branje proljetnica) te neodgovorno upravljanje vodotocima (Vuković i Nikolić 2010).

Pošto je Medvednica uvrštena u područja koja su zaštićena, a ujedno se radi i o području značajne bioraznolikosti, uz dopuštenje nadležnih ustanova ovdje se provode različiti istraživački projekti poput kartiranja i inventarizacije staništa i flore, istraživanja različitih skupina faune, istraživanja oštećenosti šumskih ekosustava, palontološka i geološka istraživanja te mnoga druga (Vuković i Nikolić 2010). Na taj način osim što se prikupljaju podaci o istraživanom području, sakupljeno znanje se u obliku mnogih znanstvenih radova, knjiga, brošura i predavanja prezentira i široj javnosti čime doprinosi edukaciji i podizanju svijesti o važnosti ovakvih područja te u konačnici doprinosi i njihovoj daljnjoj zaštiti i očuvanju.


2.2. Opis šumskih tipova (ploha)

Za svoje istraživanje analizirala sam podatke s ukupno šest ploha koje su se nalazile na južnoj padini središnjeg profila masiva Medvednice (Slika 4.). Zbog osobina rada koji je više orijentiran na metodologiju, bili su mi potrebni različiti tipovi ploha, tj. šumskih zajednica u kojima ću uzimati podatke kako bih provjerila i kvalitetno mogla testirati različite metode mjerenja raspoloživog svjetla u prizemnom sloju šumske vegetacije (jer u različitim šumskim tipovima sklop krošnji zbog različitog vegetacijskog sastava propušta različitu količinu svjetla do prizemnog sloja). Tako sam se trudila plohe birati po tipovima šumskih zajednica koje su na njima dolazile (na što je utjecala nadmorska visina i sastav tla na tim mjestima) te starosti (jer u šumama različitih starosti dolazi i do razlika u ekološkim čimbenicima, pa tako i u dostupnosti svjetla). Šumama u Parku prirode Medvednica redovito se gospodari od strane Hrvatskih šuma što na određenim područjima daje i šumske sastojine različite starosti. Polazila sam od pretpostavke da će se različit sastav i starost pojedinih šumskih zajednica očitovati u dobivenim rezultatima i doprinjeti kvalitetnijoj usporedbi i rezultatima. Istraživanje sam provela tijekom lipnja 2010. godine, tj. u godišnje doba kad je drveće u potpunosti olistalo.



Slika 4. Prikaz položaja istraživanih ploha u Parku prirode Medvednica (plohe 3 i 4 su u neposrednoj blizini jedna druge te se zbog male udaljenosti njihove točke na karti preklapaju).

Plohe broj 1 i 6 se nalaze u šumi bukve s bjelkastom bekicom (*As. Luzulo-Fagetum sylvaticae* Meusel 1937) koja pripada pod svezu srednjoeuropskih, acidofilnih bukovih šuma (Sveza *Luzulo-Fagion* Lohm. et R. Tx. in R. Tx. 1954). Ono što razlikuje ove dvije plohe jednu od druge jest starost. Na plohi broj 1 radi se o relativno mladoj šumi bukve, tj. pomladnoj šumi koja je stara 10 do 20 godina (stabla bukve su relativno niska, malog promjera te rastu veoma gusto i zatvoreno) (Slika 5.) dok je šuma na plohi broj 6 umjerene starosti (zrela visoka stabla koja imaju više prostora za daljnji rast i razvoj) (Slika 6.). Ovakve zajednice šuma, relativno siromašne vrstama, primarno dolaze na strmim i silikatnim, osiromašenim tlima na visinama od 250 do 800 m n. v., a mogu nastati i sekundarno degradacijom drugih bukovih zajednica uslijed zakiseljavanja profila tla na karbonatnoj podlozi (Vukelić i sur. 2008).




Slika 5. Ploha 1 – mlada šuma bukve s bjelkastom bekicom (foto M. Miletić)




Slika 6. Ploha 6 – umjereno stara šuma bukve s bjelkastom bekicom (foto M. Miletić)

Plohe broj 2 i 5 nalaze se u šumi bukve s velikom mrtvom koprivom (*As. Lamio orvale-Fagetumsylvaticae* Ht. 1938) koja pripada u podsvezu mezofilnih i neutrofilnih čistih bukovih šuma (Podsveza *Lamio orvale-Fagenion* Borhidi ex Marinček et al. 1993, sveza *Aremonio-Fagion* /Horvat 1938/ Borhidi in Török et al. 1989). Plohe se ponovo razlikuju po starosti šuma koje na njima dolaze. Šumu na plohi broj 2 može se definirati kao staru, a onu na plohi broj 5 kao srednje staru. Starija stabla bukve sa plohe broj 2 tako su viša, imaju veći promjer i rastu rijede s više slobodnog prostora nego ona na plohi broj 5 (Slike 7. i 8.). Ovakve šume dolaze na visinama od 400 do 800 m n. v. na područjima sjeverozapadne i

gorske Hrvatske. Nisu pretjerano zahtjevne jer ih se može naći na ravnim terenima, platoima, slabije izraženim grebenima i blagim padinama na različitim ekspozicijama. Osim toga su stabilne i pravilnog uzrasta (što ih čini idealnima za gospodarenje) te nadasve bogate ilirskim flornim elementima čime znatno doprinose bogatstvu bioraznolikosti kraja u kojem dolaze. U sjeverozapadnoj Hrvatskoj ih se obično nalazi na silikatnim tlima, a u gorskoj na vapnenačkim i dolomitnim (Vukelić i sur. 2008).



Slika 7. Ploha 2 – stara šuma bukve s velikom mrtvom koprivom (foto M. Miletić)




Slika 8. Ploha 5 – srednje stara šuma bukve s velikom mrtvom koprivom (foto M. Miletić)

Za plohu broj 3 nisam izabrala šumsku zajednicu koja prirodno dolazi na području Parka prirode Medvednica već sađenu kulturu smreke (*Picea abies* L.) (Slika 9.) za koju sam smatrala da će se dobro uklopiti u set ploha za ovo istraživanje zbog svojih posebnosti. Većina smrekovih šumskih zajednica koliko se god razlikovale imaju određene karakteristike koje su im zajedničke pa tako i ova kultura. Prvenstveno se radi o gorskom tipu šuma koje preferiraju hladniju klimu te ih se obično nalazi iznad 900 m n. v. (iznimno se mogu spustiti do 700 m n. v. samo na sjevernim stranama planinskih masiva). Karakteriziraju ih također visoka stabla kvalitetnog tvrdog drva cjenjenog u drvenoj industriji koja tvore relativno mračne šume bez velike biljne raznolikosti (Vukelić i sur. 2008).



Slika 9. Ploha 3 – sađena kultura smreke (*Picea abies* L.) (foto M. Miletić)

Kao plohu broj 4 odabrala sam panonsku bukovo-jelovu šumu s vlasuljom (As. *Festuco drymeiae-Abietetum* Vukelić et Baričević 2007) iz podsveze panonskih bukovo-jelovih šuma (Podsveza *Lamio orvale-Fagenion* Borhidi ex Marinček et al. 1993, sveza *Aremonio-Fagion* /Horvat 1938/ Borhidi in Török et al. 1989) (Slika 10.). Panonski tip bukovo-jelovih šuma za razliku od dinarskog tipa dolazi u staništima toplije klime i s manjom količinom oborina, a na Medvednici je to na zelenim škriljcima te obiluje zavičajnim zaštićenim biljnim vrstama. Te se zajednice inače nalazi na svim ekspozicijama i nagibima terena od 600 do 1000 m n. v., a na sjevernim padinama panonskih masiva mogu se spustiti i do 300 m n. v. (Vukelić i sur. 2008).



Slika 10. Ploha 4 – panonska bukovo-jelova šuma s vlasuljom (foto M. Miletić)

2.3. Terensko uzorkovanje

2.3.1. Postavljanje mjerne mreže

U svakom od šest šumskih tipova u kojima sam uzimala mjerenja postavila sam plohu 20x20 metara. Plohe su se sastojale od devet točaka smještenih u pravilnoj 3x3 mreži s međusobnom udaljenošću od 10 metara. Na svakoj od točaka sam potom uzimala podatke za svaku od tri metode za mjerenje svjetla: hemisfernu fotografiju, svjetlomjer i priručnu metodu.

2.3.2. Sklop krošnji mjeren pomoću hemisferne fotografije

Kao indirektnu metodu mjerenja svjetlosti sam u istraživanju koristila hemisfernu (fisheye) fotografiju koja na jednostavan način opisuje veličinu šumske krošnje te se veoma često koristi u istraživanjima (Jelaska 2004). Na terenu hemisferna fotografija može omogućiti detaljan opis veličine i rasporeda otvora u krošnjama te kvantitativnu mjeru ukupne otvorenosti krošnje (Engl. Canopy openness, CO) koja je definirana kao slobodan prostor u razini krošnje kojeg ne zaklanjaju grane i lišće te je mjeren iz jedne točke kad se gleda prema gore u razinu krošnje u šumi (otvorenost krošnje = 1 - zatvorenost krošnje) (Sang i sur. 2008).

Hemisferna fotografija se osim za procjenu otvorenosti krošnje može koristiti i za procjenu indeksa lisne površine (LAI) te se kod ove metode u istraživanjima najčešće koriste obje navedene značajke (Jelaska 2004, Nascimento i sur. 2006, Sang i sur. 2008). Još 1947. godine Watson je definirao LAI kao omjer jednostrane površine lista po jedinici površine tla, tj. LAI predstavlja jednu stranu lista ili polovicu svih površina lista, m^2/m^2 , dakle bez mjerne jedinice. Inače se smatra jednim od osnovnih parametara koji se pokazao ključnim u procjeni brzine rasta, akumulacije nutrijenata, prirasta biomase, kruženja ugljika, vode i energije na nivou ekosustava (Sang i sur. 2008, Santana i Encinas 2011), a do danas je poznato mnoštvo tehnika za njegovo izvođenje (Weiss i sur. 2004).

Zbog praktičnosti, u današnje vrijeme se za snimanje fotografija najviše koriste digitalni fotoaparati, iako je pokazano kako su slike snimljene analognim fotoaparatima kvalitetnije i oštrije. Korištenje digitalne fotografije preporučuje se samo u uvjetima jednolične naoblake kako bi se minimalizirao nepredvidiv učinak kromatskih aberacija (tzv. halo efekt), te uz određeni oprez kada se snima u gustim i mračnijim šumskim staništima (Frazer i sur. 2001). Glavni problem kod ove metode je prejako osvjjetljenje jer uzrokuje pretjerano i neumjereno raspršenje svjetlosti i njen lom na rubovima grana i lišća što može

dovesti do pogrešaka u mjerenjima. Točnost analize digitalnih fotografija ovisi o jasnoći rubova između različitih struktura (u ovom slučaju to su krošnja i nezaklonjeno nebo). Jasnoća rubova (oštrina) se postiže korištenjem odgovarajuće brzine snimanja, primjerenim kontrastom i osjetljivošću senzora (ISO), a kvaliteta slika se može poboljšati i povećanjem rezolucije (Guevara-Escobar i sur. 2005).


Fotografije se snimaju u prizemnom sloju šuma tako da se leća fotoaparata postavi u horizontalan položaj okrenuta prema gore i snima šumsku krošnju pomoću posebne tzv. fisheye leće (Slika 11.). U istraživanju sam koristila digitalni Nikon D60 fotoaparat sa Sigma AF 4.5/2.8 EXDC Circular Fisheye HSM objektivom. Fotoaparat je bio učvršćen na tronošću s ugrađenim libelama što je osiguravalo horizontalan položaj leće i stabiliziralo fotoaparat prilikom fotografiranja. Na svakoj od šest odabranih ploha snimila sam devet fotografija na odgovarajućim točkama unutar ploha (kako na terenu idealni uvjeti za snimanje nisu uvijek prisutni, tijekom fotografiranja sam nastojala izbjeći izravnu sunčevu svjetlost koja zasljepljuje leću i stvara bljesak na fotografijama što poslije utječe na rezultate obrade fotografija).



Slika 11. Fotoaparat s hemisfernim objektivom na tronošću (foto M. Miletić)

Prije same analize, na dobivenim fotografijama sam prvo morala ručno ukloniti odblijesak sunčevih zraka sa listova, grana, debla i tla kako prilikom obrade fotografija u programu ne bih dobila lažne rezultate (Slike 12. i 13.). Potom sam fotografije analizirala u programu «Gap Light Analyzer (GLA)» (Frazer i sur. 1999). Ovaj program snimljene


fotografije u boji pretvara u crno-bijele te potom razlučuje i računa omjer bijelog dijela (nebo, tj. otvorenost krošnje) i crnog dijela (sve ostalo što nije nebo – krošnja, debla, grmlje, tlo). Pošto se često događa da slika nije dovoljno kontrastirana te bi prilikom razlučivanja nezaklonjenog neba i krošnje moglo doći do poteškoća, slike sam prvo u GLA programu prebacila u plavi spektar kako bih im poboljšala kontrast (Slika 14.), a potom sam ručno odredila graničnu vrijednost (threshold) koja slikovne elemente (pixele) prikazuje kao crne ili bijele (Slika 15.). Na ovaj sam način odredila koji će dio slike program analizirati kao nebo, tj. otvorenost krošnje (Jelaska 2004).




Slika 12. Fotografija s označenim odbljescima svjetlosti



Slika 13. Fotografija na kojoj su označeni odbljesci svjetlosti uklonjeni




Slika 14. Hemisferna fotografija nakon prebacivanja u plavi spektar poradi poboljšanja kontrasta



Slika 15. Hemisferna fotografija nakon određivanja granične vrijednosti

Također, prije same analize, u programu sam fotografiju pomoću mreže podjelila na 9 zenitnih i 36 azimutnih djelova (Slika 16.) što mi je omogućilo da izračunam otvorenost krošnje (CO) kao postotak nezaklonjenog neba gledano ispod šumske „draperije“ (Frazer i sur. 1999).



Slika 16. Hemisferna fotografija podjeljena u 9 zenitnih i 36 azimutnih djelova

2.3.3. Sklop krošnji mjeren svjetlomjerom

U istraživanju sam kao direktnu metodu za mjerenje svjetlosti koristila svjetlomjer. Svjetlomjer ili lux-metar je instrument koji služi za mjerenje apsolutnog iznosa svjetla. Sadrži ćelije osjetljive na svjetlost koje pretvaraju svjetlosne zrake u električnu struju ili mijenjaju jačinu struje što protječe od male baterije u kameri do ćelija. U oba slučaja ulaskom svjetlosti u svjetlomjer pojačava se jakost struje, a uređaj očitava svjetlost i iskazuje očitano u određenim jedinicama. Svjetlomjer korišten u ovom istraživanju Light Meter PCE-L335 stavila sam da očitava svjetlost u jedinicama rasvjetljenosti - luksima (lx) (Slika 17.).

Jedan od nedostataka ove metode jest to što se mjerenja moraju provoditi s uparenim instrumentima, tj. istovremeno se očitava iznos svjetlosti na točki pod šumskom „draperijom“ i na otvorenom prostoru te se dobiveni iznosi potom stavljaju u omjer. To znači da su za istraživanje u tom slučaju potrebna dva mjerna instrumenta i dvoje ljudi koji će očitavati iznose na njima. U istraživanju mi je pomogla kolegica koja je s jednim svjetlomjerom stajala na otvorenom prostoru van šume dok sam ja s drugim mjerila količinu svjetlosti na odabranim šumskim plohama (Slika18.). Kako smo iznose svjetlosti morale na instrumentima očitavati

istovremeno (radi valjanosti usporedbe podataka), za dogovor za sinhronizirani rad smo se koristile prijenosnim radio primopredajnicima marke Motorola, tzv. walkie-talkie (Slika 17.).

Na svakoj od ploha sam uzimala mjerenja na svih devet označenih točaka, s time da sam na svakoj točki napravila ukupno pet očitavanja instrumenta, iz čega sam nakon što sam svako očitavanje stavila u omjer s onim izmjerenim na otvorenom prostoru, na kraju izračunala aritmetičku sredinu za svaku od odabranih točaka.



Slika 17. Svjetlomjer Light Meter PCE-L335 i Motorola prijenosni radio primopredajnik (walkie-talkie) (foto M. Miletić)



Slika 18. Upotreba svjetlomjera (foto M. Miletić)

2.3.4. Sklop krošnji mjeren priručnom metodom

Još 1949. godine Garrison je predložio model instrumenta za mjerenje otvorenosti šumske krošnje naziva *moosehorn*. Instrument se sastojao od 25 točkica smještenih u pravilnoj 5x5 mreži, naslikanih na prozirnom zaslonu. Koristio se tako što je promatrač gledao vertikalno prema gore kroz zaslon i brojao točke koje su se poklapale s otvorima u krošnji (Brown i sur. 2000). Uskoro se pokazalo kako je ovakav instrument prilično nezgrapnan i krhak za učestalu primjenu na terenima pa su u njegovu dizajnu napravljene određene izmjene.

U istraživanju sam koristila pojednostavljenu verziju ovog instrumenta koju su predložili Brown i sur. (2000) nazvavši je *canopy-scope*, a koja se sastojala od prozirne pločice perspeksa (dalje u radu zvanom Plexi) na kojoj je bilo označeno 25 točkica u pravilnoj 5x5 mreži međusobno udaljenih 3 cm. Na pločicu je bilo pričvršćeno ravvalo s libelom kako

bi se pri gledanju kroz nju okomito u vis moglo vidjeti je li u pravilnom položaju, tj. gleda li točno u zenit (Slika 19.). U donjem desnom kutu pločice bio je pričvršćen konopac označene duljine od 20 cm koji je služio za mjerenje udaljenosti pločice od oka promatrača, tj. osiguravao da ta udaljenost pri svakom mjerenju bude ista (Slika 20.). Na svakoj od devet točaka na odabranim šumskim ploham napravila sam jedno očitavanje instrumenta. Iznos otvorenosti krošnje sam računala iz omjera točkica koje su se poklapale s rupama u šumskoj krošnji i ukupnog broja točkica (25).



Slika 19. Izgled priručnoga instrumenta, tzv. Plexi
(foto M. Miletić)




Slika 20. Upotreba Plexi instrumenta
(foto M. Miletić)

2.4. Obrada podataka

2.4.1. Analiza podataka dobivenih trima metodama za mjerenje svjetlosti

Kako sam za svaku od šest odabranih ploha imala po devet podataka od svake od tri korištene metode za mjerenje svjetlosti raspoređenih unutar plohe, koristila sam pet kombinacija za računanje njihove srednje vrijednosti. Prva je kombinacija bila računanje aritmetičke sredine iz vrijednosti dobivenih na svih devet točaka za svaku metodu unutar plohe (oznake: za svjetlomjer - LUXmean, za hemisfernu fotografiju – COmean, za priručnu metodu – PLEXmean). Druga je kombinacija bila računanje aritmetičke sredine bez najmanje i najveće vrijednosti (oznake: za svjetlomjer – LUXmmm, za hemisfernu fotografiju – COmmm, za priručnu metodu – PLEXmmm). Treća je kombinacija bila računanje aritmetičke sredine iz vrijednosti 1., 3., 5., 7. i 9. točke na plohi (oznake: za svjetlomjer – LUX19, za hemisfernu fotografiju – CO19, za priručnu metodu – PLEX19). Četvrta kombinacija je bila

računanje aritmetičke sredine iz vrijednosti 2., 4., 5., 6. i 8. točke na plohi (oznake: za svjetlomjer – LUX28, za hemisfernu fotografiju – CO28, za priručnu metodu – PLEX28). Kao zadnju kombinaciju sam uzela jednostavno samo središnju vrijednost svake plohe, tj. točku 5. (oznake: za svjetlomjer – LUX5, za hemisfernu fotografiju – CO5, za priručnu metodu – PLEX5). Shema za izračunavanje četiri kombinacije podataka na odabranim ploham (bez druge kombinacije koja ne uključuje najveću i najmanju vrijednost) prikazana je na slici 21.



Slika 21. Prikaz četiri kombinacije za računanje srednjih vrijednosti iz devet točaka na zadanoj plohi. Prva je kombinacija računanja aritmetičke sredine iz podataka za svih devet točaka na plohi (LUXmean, COmean i PLEXmean). Druga je računanje aritmetičke sredine iz podataka za točke 1., 3., 5., 7. i 9. (LUX19, CO19 i PLEX19). Treća je računanje aritmetičke sredine iz podataka za točke 2., 4., 5., 6., i 8. (LUX28, CO28 i PLEX28). Zadnja je kombinacija uzimanje samo središnje vrijednosti plohe, tj. točke 5. (LUX5, CO5 i PLEX5).

Navedene kombinacije podataka koristila sam u svrhu testiranja koliko je mjerenja svake metode po plohi šumske vegetacije dovoljno da bi se postigli približno jednaki rezultati. Usporedbu unutar metoda kako bih vidjela postoji li značajna razlika na razini plohe u korištenju pet kombinacija za računanje srednjih vrijednosti napravila sam Friedman ANOVA testom.

2.4.2. Analiza linearne koreliranosti za parove metoda

Kako bih provjerila koliko sukladno variraju vrijednosti između metoda koje sam koristila za mjerenje svjetlosti te njihovu međusobnu povezanost, upotrijebila sam linearnu korelaciju i odredila koeficijente korelacije za parove metoda: Svjetlomjer vs. Plexi, Plexi vs. Hemisferna i Hemisferna vs. Svjetlomjer.

2.4.3. Testiranje razlika srednjih vrijednosti triju metoda za mjerenje svjetlosti Friedman ANOVA sumom rangova

U statistici, analiza varijance (ANOVA) je skup statističkih modela koji se koriste za testiranje razlika između pojedinih setova podataka. Friedman ANOVA neparametrijskim testom moguće je ustanoviti jesu li srednje vrijednosti dviju ili više zavisnih skupina podataka jednake. U ovom sam istraživanju testirala srednje vrijednosti triju metoda za mjerenje svjetlosti kako bih provjerila razlikuju li se njihove srednje vrijednosti.

3. Rezultati

3.1. Podaci dobiveni mjerenjem svjetlosti i rezultati njihove analize

U tablici 1. Prikazani su podaci o količini raspoloživog svjetla (u postocima) dobiveni na terenu trima metodama za mjerenje svjetla u prizemnom sloju šumske vegetacije.

Tablica 1. Prikaz podataka dobivenih trima metodama mjerenja svjetla na devet točaka unutar šest ploha šumske vegetacije (svjetlomjera (LUX), hemisferne fotografije (CO) i priručne metode (PLEX)) u postocima.

PLOHA	TOČKA	LUX (%)	CO(%)	PLEX(%)
1	1	1,54	2,89	20
1	2	1,97	3,49	16
1	3	8,60	3,97	20
1	4	1,36	3,31	16
1	5	1,55	2,91	24
1	6	2,65	3,89	44
1	7	1,35	4,10	20
1	8	1,14	4,00	20
1	9	2,05	3,74	44
2	1	8,61	9,06	76
2	2	100,70	7,93	64
2	3	5,84	5,91	48
2	4	7,27	7,86	52
2	5	98,69	5,29	56
2	6	3,44	2,86	32
2	7	6,26	5,84	44
2	8	10,02	3,93	48
2	9	37,63	1,60	40
3	1	1,41	0,96	24
3	2	0,55	0,92	28
3	3	0,376	0,90	28
3	4	0,37	0,62	20
3	5	0,41	1,81	16
3	6	0,39	1,17	28
3	7	0,55	3,64	16
3	8	0,24	0,94	16
3	9	0,34	1,28	24
4	1	1,51	1,79	24
4	2	1,63	1,87	20
4	3	4,73	2,82	24
4	4	1,24	2,47	32
4	5	1,32	2,25	24
4	6	1,04	1,89	20
4	7	0,84	1,40	20
4	8	1,05	2,04	16
4	9	0,85	1,62	16
5	1	7,75	1,09	24


5	2	11,24	1,96	28
5	3	21,27	4,55	28
5	4	7,97	1,23	20
5	5	11,84	2,95	20
5	6	14,42	2,00	28
5	7	8,66	0,63	28
5	8	9,45	1,28	28
5	9	12,08	1,71	28
6	1	4,31	3,39	28
6	2	2,71	1,72	20
6	3	12,15	3,58	40
6	4	15,50	3,98	28
6	5	19,30	1,43	16
6	6	11,23	3,01	24
6	7	36,85	5,74	20
6	8	15,36	3,16	24
6	9	29,08	2,76	36

U tablici 2. Prikazano je pet kombinacija srednjih vrijednosti koje sam izračunala za sve tri metode mjerenja svjetla na šest odabranih ploha.


Tablica 2. Prikaz rezultata dobivenih izračunom pet kombinacija srednjih vrijednosti mjerenja raspoloživog svjetla trima metodama na šest odabranih ploha šumske vegetacije. Oznake za kombinacije računanja srednjih vrijednosti opisane su u metodama analiza podataka dobivenih trima metodama za mjerenje svjetlosti i pod slikom 21.

	PLOHA 1	PLOHA 2	PLOHA 3	PLOHA 4	PLOHA 5	PLOHA 6
LUXmean	2,47	30,94	0,51	1,58	11,63	16,28
LUXmmm	1,78	24,90	0,43	1,23	10,81	15,28
LUX19	3,02	31,41	0,62	1,85	12,32	20,34
LUX28	1,73	44,03	0,39	1,26	10,98	12,82
LUX5	1,55	98,69	0,41	1,32	11,84	19,30
Comean	3,59	5,59	1,36	2,02	1,93	3,20
Commm	3,62	5,66	1,14	1,99	1,75	3,09
CO19	3,52	5,54	1,72	1,98	2,19	3,38
CO28	3,52	5,57	1,09	2,10	1,88	2,66
CO5	2,91	5,29	1,81	2,25	2,95	1,43
PLEXmean	24,88	51,11	22,22	21,77	25,77	26,22
PLEXmmm	23,43	50,29	22,29	21,14	26,29	25,71
PLEX19	25,60	52,80	21,60	21,60	25,60	28,00
PLEX28	24,00	50,40	21,60	22,40	24,80	22,40
PLEX5	24,00	56,00	16,00	24,00	20,00	16,00


Iz dobivenih podataka mogu se vidjeti razlike u količini raspoložive svjetlosti na odabranim plohama šumske vegetacije. Slike 22., 23. i 24. prikazuju razlike u količini dostupne svjetlosti po plohama različitih šumskih tipova mjerene trima metodama (Slika 22. LUX – svjetlomjer, Slika 23. CO – hemisferna fotografija, Slika 24. PLEX – priručna metoda) i u svih pet računanih kombinacija srednjih vrijednosti. Tako se može primjetiti kako je na plohi br. 2 (stara šuma bukve s velikom mrtvom koprivom) svim metodama i u svim kombinacijama zabilježena najveća količina svjetlosti, dok je najmanja najčešće zabilježena na plohama br. 3 (sađena kultura smreke) i 4 (panonska bukovo-jelova šuma s vlasuljom). Također se primjećuje kako su podaci za hemisfernu fotografiju i priručnu metodu ujednačeni u svih pet kombinacija srednjih vrijednosti za sve plohe, dok se kod metode svjetlomjera vidi velika neujednačenost podataka za plohu br. 2.



Slika 22. Razlike u količini dostupne svjetlosti (%) po plohama različitih šumskih tipova mjereno svjetlomjerom.



Slika 23. Razlike u količini dostupne svjetlosti (%) po plohama različitih šumskih tipova mjereno hemisfernom fotografijom.



Slika 24. Razlike u količini dostupne svjetlosti (%) po plohama različitih šumskih tipova mjereno priručnom metodom.

Friedman ANOVA testom unutar triju metoda mjerenja svjetlosti ustanovila sam da postoji značajna razlika na razini plohe između pet kombinacija srednjih vrijednosti za metodu svjetlomjera na razini cjelog uzorka. Za metode mjerenja svjetlosti hemisfernom fotografijom i priručnom metodom nema značajne razlike na razini plohe koju između pet kombinacija za izračun srednjih vrijednosti koristimo (Tablice 4. i 5.).

Tablica 3. Rezultati Friedman ANOVA testa za srednje vrijednosti metode mjerenja raspoloživog svjetla svjetlomjerom (χ^2 (N=6, df=4) = 12.67, **p = 0.01**, Koef. konk. = 0.53, Prosječni rang r = 0.43).

Varijabla	Prosječni rang	Suma rangova	Srednja vrijednost	Std.devijacija
LUXmean	3,33	20,00	10,57	11,80
LUXmmm	1,83	11,00	9,07	9,81
LUX19	4,67	28,00	11,59	12,32
LUX28	2,00	12,00	11,87	16,63
LUX5	3,17	19,00	22,18	38,22


Tablica 4. Rezultati Friedman ANOVA testa za srednje vrijednosti metode mjerenja raspoloživog svjetla hemisfernom fotografijom (χ^2 (N=6, df=4) = 1.73, p = 0.78, Koef. konk. = 0.07, Prosječni rang r = -0.11).

Varijabla	Prosječni rang	Suma rangova	Srednja vrijednost	Std.devijacija
COmean	3,50	21,00	2,95	1,54
COmmm	3,00	18,00	2,87	1,64
CO19	3,17	19,00	3,05	1,43
CO28	2,33	14,00	2,81	1,58
CO5	3,00	18,00	2,77	1,37

Tablica 5. Rezultati Friedman ANOVA testa za srednje vrijednosti metode mjerenja raspoloživog svjetla priručnom metodom (χ^2 (N=6, df=4) = 3.22, p = 0.52, Koef. konk. = 0.13, Prosječni rang r = -0.04).

Varijabla	Prosječni rang	Suma rangova	Srednja vrijednost	Std.devijacija
PLEXmean	3,67	22,00	28,66	11,15
PLEXmmm	2,67	16,00	28,19	11,00
PLEX19	3,58	21,50	29,20	11,83
PLEX28	2,50	15,00	27,60	11,23
PLEX5	2,58	15,50	26,00	15,13

Raspon podataka izmjerenih vrijednosti za metodu mjerenja svjetlosti svjetlomjerom prikazan je Box-Whisker prikazom (Slika 25.). Uočljiv je veći raspon podataka pri korištenju zadnje kombinacije za izračun srednjih vrijednosti, tj. one za koju su samo jednostavno uzete vrijednosti središnjih točaka ploha (točke br. 5 na ploham).



Slika 25. Box-Whisker prikaz raspona srednjih vrijednosti metode mjerenja svjetlosti svjetlomjerom s medijanama i kvartalima. Raspon srednjih vrijednosti za zadnju kombinaciju kod koje su za izračun uzete samo središnje točke ploha (točke br. 5) se značajno ističe.

3.2. Rezultati linearne koreliranosti za parove metoda

Testom linearne korelacije provjerila sam sličnosti unutar parova triju metoda za mjerenje svjetlosti, tj. koliko sukladno variraju njihove vrijednosti. Izračunala sam koeficijente korelacije za parove metoda (Svjetlomjer vs. Plexi, Plexi vs. Hemisferna i Hemisferna vs. Svjetlomjer) na svakoj od šest istraživanih ploha te na kraju aritmetičku sredinu (prosjeck) za svaki od parova metoda i za svaku od istraživanih ploha (Tablica 6.).

Statistički značajne korelacije (otisnute masnim slovima) uočene su u parovima priručne metode – Plexi i hemisferne fotografije (PLEXmean vs. COMean) te hemisferne fotografije i svjetlomjera (COMean vs. LUXmean). Ako se gledaju korelacije unutar pojedinih ploha, najviše vrijednosti korelacija imala je ploha br. 4 (panonska bukovo-jelova šuma s vlasuljom). Najmanje vrijednosti korelacije imala je ploha br. 3 (sađena kultura smreke) čiji je prosjek korelacija na kraju bio i negativan (desni prosjek), što nije u skladu s očekivanjima jer se pretpostavljalo da će povećanja vrijednosti podataka jedne od metoda pratiti povećanja vrijednosti podataka druge metode, što se u ovom slučaju nije dogodilo.

Konačne korelacije za parove (donji prosjek) su pozitivne što pokazuje povezanost između parova (vrijednosti izmjerene jednom od metoda prate vrijednosti druge metode unutar ploha). Vidljive su zato razlike između parova metoda. Značajna povezanost (statistički značajni koeficijent korelacije) uočava se tek kod usporedbe metoda hemisferne fotografije i svjetlomjera (COMean vs. LUXmean). Za parove svjetlomjera i priručne metode – Plexi (LUXmean vs. PLEXmean) te priručne metode - Plexi i hemisferne fotografije (PLEXmean vs. COMean) vrijednost korelacije je neznatna (LUXmean vs. PLEXmean) ili mala (PLEXmean vs. COMean).

Tablica 6. Prikaz koeficijenata korelacija unutar parova triju metoda za mjerenje svjetlosti na šest istraživanih ploha. Statistički značajne korelacije ($p < 0.05$) otisnute su masnim brojkama, a prosjeci za parove metoda (dolje) i svaku od istraživanih ploha (desno) ukošenim.

	LUXmean vs. PLEXmean	PLEXmean vs. COMean	COMean vs. LUXmean	PROSJEK
PLOHA 1	-0,014	0,234	0,325	0,181
PLOHA 2	0,338	0,833	0,101	0,423
PLOHA 3	0,163	-0,508	-0,009	-0,117
PLOHA 4	0,256	0,588	0,737	0,526
PLOHA 5	0,361	0,026	0,913	0,433
PLOHA 6	-0,023	0,186	0,520	0,228
PROSJEK	0,180	0,227	0,431	

3.3. Rezultati testiranja razlika srednjih vrijednosti triju metoda za mjerenje svjetlosti Friedman ANOVA sumom rangova

Kod usporedbe triju metoda za mjerenje svjetlosti Friedman ANOVA testom sume rangova ustanovila sam na temelju dviju kombinacija srednjih vrijednosti (one kod koje se računa aritmetička sredina iz svih devet točaka na plohi (Tablica 7.) i one kod koje se računa aritmetička sredina bez najmanje i najveće izmjerene vrijednosti na određenoj plohi (Tablica 8.) statistički značajnu razliku između priručne metode i ostalih dviju metoda (svjetlomjera i hemisferne fotografije).

Tablica 7. Rezultati Friedman ANOVA testa za tri metode mjerenja svjetlosti kod kombinacije izračuna srednjih vrijednosti u kojoj su korišteni podaci svih devet točaka istraživanih ploha. Rezultat za priručnu metodu (PLEXmean) se značajno razlikuje od rezultata za ostale dvije metode (χ^2 (N=6, df=2) = 9.00, **p = 0.01**, Koef. konk. = 0.75, Prosječni rang r = 0.70).

Varijabla	Prosječni rang	Suma rangova	Sr. vrijednost	Std.devijacija
PLEXmean	3,00	18,00	28,66	11,15
LUXmean	1,50	9,00	10,57	11,80
COmean	1,50	9,00	2,95	1,54

Tablica 8. Rezultati Friedman ANOVA testa za tri metode mjerenja svjetlosti kod kombinacije izračuna srednjih vrijednosti u kojoj su korišteni podaci bez najveće i najmanje vrijednosti na plohi. Rezultat za priručnu metodu (PLEXmmm) se značajno razlikuje od rezultata za ostale dvije metode (χ^2 (N=6, df=2) = 9.000000, **p = 0.01111**, Koef. konk. = 0.75000, Prosječni rang r = 0.70000).

Varijabla	Prosječni rang	Suma rangova	Sr. vrijednost	Std.devijacija
PLEXmmm	3,00	18,00	28,19	11,00
LUXmmm	1,50	9,00	9,07	9,81
COmmm	1,50	9,00	2,87	1,64

4. Rasprava

Dobiveni rezultati nisu potvrdili polaznu hipotezu da ne bi trebalo biti značajnih razlika između istraživanih metoda za mjerenje svjetlosti. Statističke analize su pokazale kako se rezultati priručne metode značajno razlikuju od onih dobivenih svjetlomjerom i hemisfernom fotografijom. Uzrok tome može biti subjektivnost i neiskustvo ispitivača, nemirna ruka ili loše postavljen mjerni instrument koji sigurno mogu značajno utjecati na točnost podataka. Činjenica je da nijedna od navedenih metoda za mjerenje raspoloživog svjetla nije nepogrešiva i da u svakoj na rezultate može utjecati ljudski faktor. Kod svjetlomjera potrebna su dva mjerna instrumenta i dvoje ispitivača koji moraju biti dobro usklađeni za rad na terenu. Kod snimanja hemisfernih fotografija na izgled i kvalitetu snimki mogu značajno utjecati vremenske prilike na terenu, jer idealni uvjeti snimanja su relativno rijetki tokom dana i zahtjevali bi dulji vremenski period ovakvog istraživanja. Obrada fotografija koja slijedi nakon toga, ukoliko se radi o lošijim snimkama, može sadržavati određenu dozu nesigurnosti i subjektivnosti. Dakle, što su snimke bolje, manja je potreba za ručnim uklanjanjem odbljesaka sunčevih zraka i određivanjem granične vrijednosti (threshold) u programu za obradu slika te se time smanjuje ljudski faktor i mogućnost za pogreške. Ova se metoda često smatra nepouzdanom u uvjetima slabije osvjetljenosti (Machado i Reich 1999) kada je šumski pokrov gušći jer već male razlike u određivanju graničnih vrijednosti u programu za obradu podataka mogu dati velike razlike u rezultatima (Jennings i sur. 1999).

Činjenica je i da se kod priručne metode otvorenost krošnje mjeri postavljanjem instrumenta da gleda točno u zenit, a mjerno polje ograničeno je njegovom veličinom, u obzir se ne uzimaju otvori u krošnji s ruba mjernog instrumenta niti svjetlost koja dolazi postrance ili sa rubova šume, a što se kod mjerenja svjetlomjerom i hemisfernom fotografijom događa jer ti instrumenti nisu u mjerenjima ograničeni strogo na zenit te je moguće da je i to jedan od razloga zašto su međusobno bolje korelirani i daju sličnije rezultate. Dapače, Brown i sur. (2000) su u svom istraživanju zaključili kako je priručna metoda imala dobru korelaciju s metodom hemisfernih fotografija koju drže najpreciznijom od istraživanih metoda (u ovom istraživanju priručna metoda je također bila bolje korelirana s metodom hemisferne fotografije nego li sa svjetlomjerom). Prednosti su joj još i što se mjerni instrument lako može napraviti i kod kuće, praktičan je, ne zauzima puno prostora niti zahtjeva posebna znanja za potrebe rukovanja njime te je jeftin. Fiala i sur. (2006) sličan instrument naziva *moosehorn* ističu kao najbržu i najlakšu metodu za mjerenje svjetlosti.

Mogu reći da općenito na razini ploha nema značajnih razlika hoće li se u rezultatima koristiti jedno ili više mjerenja, ali u slučaju metode svjetlomjera ipak su se pokazale značajne razlike u takvim mjerenjima, a nadasve je vidljiv veći raspon vrijednosti kada se za procjenu količine raspoložive svjetlosti uzimala samo središnja vrijednost ploha (točka 5). Zbog veće sigurnosti, preporučila bih ipak provođenje većeg broja mjerenja po plohi, ne samo zbog svjetlomjera na čije rezultate čini se više utječu vremenske prilike (poput naoblake i vjetera što se najviše primjetilo na plohi br. 2 - stara šuma bukve s velikom mrtvom koprivom, gdje su rupe u krošnjama bile najveće te je pod utjecajem vremenskih prilika u podacima s te plohe bilo i najviše kolebanja) i zbog osjetljivijeg sustava mjerenja svjetlosti u luksima što povećava raspon rezultata dobivenih njegovim mjerenjem, već i zbog drugih metoda. Za hemisfernu fotografiju tako je korisnije imati veći broj snimaka po plohi, pogotovo u slučajevima kad svjetlosni uvjeti nisu idealni, a za priručnu metodu zbog potencijalne nesigurnosti i neiskustva ispitivača. Inače se smatra da pouzdanost i točnost podataka raste s njihovim brojem tako da se i za metode koje su se pokazale preciznima ipak preporučuje barem 20 i više uzoraka po plohi (Laymon 1988, iz Ganey i Block 1994), dok Jennings i sur. (1999) smatraju kako je manje od 100 uzoraka po plohi od slabe koristi pri razlikovanju šumskih ploha sličnog sastava krošnje.

Što se tiče razlika u količini raspoložive svjetlosti u prizemnom sloju šume između samih ploha, grafički prikazi pokazali su kako one definitivno postoje. Ploha br. 2 (stara šuma bukve s velikom mrtvom koprivom) tako se pokazala najsvjetlijom, a plohe br. 3 (sađena kultura smreke) i 4 (panonska bukovo-jelova šuma s vlasuljom) najtamnijima. Razlog tome je različitost samih šumskih zajednica koje dolaze na tim plohami (jer sastav vegetacije oblikuje šumsku krošnju kroz koju svjetlost dolazi do prizemnog sloja u šumi). Smrekove šume su inače karakterizirane kao mračne (Vukelić i sur. 2008) što se u ovom istraživanju pokazalo točnim, dok se za staru bukovu šumu moglo pretpostaviti da će imati najveću količinu raspoloživog svjetla jer je po svom sastavu bila otvorenija, s više slobodnog prostora među drvećem te većim rupama u krošnji.

Ploha br. 3 je također imala najslabiju korelaciju među parovima metoda, a koja je u prosjeku imala i negativan predznak, što još jednom ukazuje na potreban oprez kod uzimanja podataka na plohami gdje je slabija osvjetljenost. Zanimljivo je što se od svih ploha kao ona s najvišom korelacijom pokazala ploha br. 4, na kojoj je također zabilježena veoma niska količina raspoložive svjetlosti, što bi ju inače trebalo učiniti nepouzdanom za istraživanja. No kako bi se mogli izvući kvalitetniji zaključci o pouzdanosti određenih šumskih tipova i ploha,

smatram da bi analizu ipak bilo potrebno provesti s ponavljanjima u više ploha istih tipova šuma.

Potrebno je naglasiti kako ne postoji «najbolja metoda» već da svaka od mjera i instrumenata ima svoje posebne karakteristike, te bi se pri odabiru dotičnih trebalo povoditi specifičnom prirodom i zahtjevima pojedinih istraživanja (Jennings i sur. 1999). U budućim istraživanjima ne bih smanjivala broj uzoraka po plohama na kojima se provode istraživanja jer u nekim slučajevima oni očito igraju značajnu ulogu u pouzdanosti i dosljednosti rezultata. Za metodu svjetlomjera bi bilo zanimljivo ispitati bi li i dalje postojala značajna razlika unutar metode za različite kombinacije računanja srednjih vrijednosti ukoliko bi se povećao broj mjerenja po istraživačkoj plohi. Kako se priručna metoda pokazala nepouzdanijom u usporedbi s druge dvije, bio bi zanimljivo vidjeti bi li se njena pouzdanost povećala s povećanjem broja podataka na istraživačkim plohama (jer pouzdanost unutar same metode očito postoji). Općenito bi za istraživanje bilo bolje da se provodi u idealnijim vremenskim i svjetlosnim uvjetima koji očito mogu utjecati na dobivene podatke, a samim time i na konačan rezultat.

5. Zaključci

Mogla bih zaključiti kako se od triju ispitivanih i usporedivnih metoda hemisferna fotografija ipak, usprkos nedostacima i nepouzdanostima koje se mogu javiti ako svjetlosni uvjeti nisu idealni, pokazala najpouzdanijom za mjerenje raspoložive količine svjetlosti u prizemnom sloju šumske vegetacije. Nedostaci ove metode mogu još biti skupoća i nepraktičnost opreme, ali ona to nadoknađuje kvalitetom podataka koji su njome dobiveni.

Metoda mjerenja svjetlosti svjetlomjerom je pokazala da može općenito dati zadovoljavajuće rezultate, ali zbog velikog raspona podataka unutar metode zaključujem da je ipak pod većim utjecajem okolišnih faktora (vremenskih prilika) upravo zbog svoje visoke osjetljivosti detektiranja promjena svjetlosti, a nepraktičnom ju također čini i to što je za njeno provođenje potrebno dvoje ljudi.

Priručna metoda se pokazala pouzdanom za mjerenja unutar same metode jer rasip dobivenih podataka nije bio velik, no u usporedbi sličnosti s druge dvije metode ipak u pouzdanosti rezultata zaostaje za njima. Držim da je to bila posljedica neiskustva ispitivača i razlike u načinu mjerenja količine svjetlosti između metoda jer su druge dvije metode osjetljivije na svjetlost koja dolazi i s bočnih strana, a ne samo direktnu iz zenita kao ova metoda, što smatram da ipak može ujecati na krajnje rezultate. Uz dovoljan broj podataka po istraživačkoj plohi i određenu dozu pažnje i vježbe, držim da ova metoda može biti dovoljno dobra za mjerenje raspoložive svjetlosti u prizemnom sloju šumske vegetacije. Dodatni plus ovoj metodi jest što je jeftina, brza i laka za izvođenje.

6. Literatura

- Asner G. P., Keller M., Pereira Jr. R., Zweede J. C., Silva J. N. (2004): Canopy Damage and Recovery Following Selective Logging in an Amazon Forest: Integrating Field and Satellite Studies. *Ecological Applications* 14: (4) 280-298.
- Azizi Z., Najafi A., Sohrabi H. (2008): Forest canopy density estimating, using satellite images. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37: (B8) 1127-1130.
- Bašić-Zaninović T., Perić N. (2004): *Biologija – putovanje kroz život*. Kugler, Zagreb.
- Basset Y., Charles E., Hammond D. S., Brown V. K. (2001): Short-term effects of canopy openness on insect herbivores in a rain forest in Guyana. *Journal of Applied Ecology* 38: 1045-1058.
- Beaudet M., Messier C. (2002): Variation in canopy openness and light transmission following selection cutting in northern hardwood stands: an assessment based on hemispherical photographs. *Agricultural and Forest Meteorology* 110: 217-228.
- Brown N., Jennings S., Wheeler P., Nabe-Nielsen J. (2000): An improved method for the rapid assessment of forest understorey light environments. *Journal of Applied Ecology* 37: 1044-1053.
- Capers R. S., Chazdon R. L. (2004): Rapid assessment of understory light availability in a wet tropical forest. *Agricultural and Forest Meteorology* 123: 177-185.
- Chacón P., Armesto J. J. (2005): Effect of canopy openness on growth, specific leaf area, and survival of tree seedlings in a temperate rainforest of Chiloé Island, Chile. *New Zealand Journal of Botany* 43: 71-81.
- Comita L. S., Uriarte M., Thompson J., Jonckheere I., Canham C. D., Zimmerman J. K. (2009): Abiotic and biotic drivers of seedling survival in a hurricane-impacted tropical forest. *Journal of Ecology* 97: (6) 1346-1359.
- Devkota N. R., Wall A. J., Kemp P. D., Hodgson J. (2001): Relationship between canopy closure and pasture. Production in deciduous tree based temperate silvopastoral systems., <http://www.internationalgrasslands.org/files/igc/publications/2001/id1803.pdf>; pristupljeno 16.2.2011.
- Dickinson M. B., Putz F. E., Canham C. D. (1993): Canopy gap closure in thickets of the clonal shrub, *Cornus racemosa*. *Bulletin of the Torrey Botanical Club* 120: (4) 439-444.

- Dottavio C. L. (1981): Effect of Forest Canopy Closure on Incoming Solar Radiance. LARS Symposia. Paper 447., http://docs.lib.purdue.edu/lars_symp/447; pristupljeno 16.6.2010.
- Fiala A. C. S., Garman S. L., Gray A. N. (2006): Comparison of five canopy cover estimation techniques in the western Oregon Cascades. *Forest Ecology and Management* 232: 188-197.
- Frazer G. W., Canham C. D., Lertzman K. P. (1999): Gap Light Analyzer (GLA), Version 2.0: Imaging software to extract canopy structure and gap light transmission indices from true-colour fisheye photographs, users manual and program documentation. Simon Fraser University, Burnaby, British Columbia, and the Institute of Ecosystem Studies, Millbrook, New York, 36 pp.
- Frazer G. W., Fournier R. A., Trofymow J. A., Hall R. J. (2001): A comparison of digital and fisheye photography for analysis of forest canopy structure and gap light transmission. *Agricultural and Forest Meteorology* 109: 249-263.
- Ganey J. L., Block W. M. (1994): A Comparison of Two Techniques for Measuring Canopy Closure. *Western Journal of Applied Forestry* 9: (1) 21-23.
- Gong P., Miller J. R., Spanner M. (1994): Forest Canopy Closure from Classification and Spectral Unmixing of Scene Components – Multisensor Evaluation of an Open Canopy. *IEEE Transactions on Geoscience and Remote Sensing* 32: (5) 1067-1080.
- Gračanin M., Ilijanić LJ. (1977): Uvod u ekologiju bilja. Školska knjiga, Zagreb.
- Grove S. J., Turton S. M., Siegenthaler D. T. (2000): Mosaics of canopy openness induced by tropical cyclones in lowland rain forests with contrasting management histories in northeastern Australia. *Journal of Tropical Ecology* 16: 883-894.
- Guevara-Escobar A., Tellez J., Gonzalez-Sosa E. (2005): Use of digital photography for analysis of canopy closure. *Agroforestry Systems* 65: 175-185.
- Gurevitch J., Scheiner S. M., Fox G. A. (2002): *The Ecology of Plants*. Sinauer Associates, Inc., Sunderland, Massachusetts, U.S.A.
- Hadi F., Wikantika K., Sumarto I. (2004): Implementation of Forest Canopy Density Model to Monitor Forest Fragmentation in Mt. Simpang and Mt. Tilu Nature Reserves, West Java, Indonesia., http://www.fig.net/pub/jakarta/papers/ts_21/ts_21_4_hadi_et al.pdf; pristupljeno 16.2.2011.
- Haywood D. D., Miller C. R. (1995): Assessment of Canopy Closure. Projections by the PROGNOSIS Model., http://sbosc.wr.usgs.gov/cprs/news_info/meetings/biennial/proceedings/1995/biological_resources/HaywoodandWakeling.pdf; pristupljeno 16.2.2011.

- He Y., Guo X., Wilmschurst J. F. (2007): Comparison of different methods for measuring leaf area index in a mixed grassland. *Canadian Journal of Plant Science* 87: (4) 803-813.
- Jelaska S. D. (2004): Analysis of canopy closure in the Dinaric silver fir – beech forests (*Omphalodo-Fagetum*) in Croatia using hemispherical photography. *Hacquetia* 3: (2) 43-49.
- Jennings S. B., Brown N. D., Sheil D. (1999): Assessing forest canopies and understorey illumination: canopy closure, canopy cover and other measures. *Forestry* 72: (1) 59-73.
- Klassen S. P., Ritchie G., Frantz J. M., Pinnock D., Bugbee B. (2003): Real-time imaging of ground cover: Relationships with radiation capture, canopy photosynthesis, and daily growth rate., <http://www.usu.edu/cpl/PDF/Ground%20Cover%20Final%20Edit%20readable.pdf>; pristupljeno 16.2.2011.
- Knowles R. L., Horvath G. C., Carter M. A., Hawke M. F. (1999): Developing a canopy closure model to predict overstorey/understorey relationships in *Pinus radiata* silvopastoral systems. *Agroforestry Systems* 43: 109-119.
- Korhonen L., Kaartinen H., Kukko A., Solberg S., Astrup R. (2010): Estimating vertical canopy cover with terrestrial and airborne laser scanning. *Proceedings of Silvilaser 2010*, September 14-17, Freiburg, Germany. 11 p., <http://ff.joensuu.fi/~lakorhon/>; pristupljeno 16.2.2011.
- Korhonen L., Korhonen K. T., Raiutiainen M., Stenberg P. (2006): Estimation of Forest Canopy Cover: a Comparison of Field Measurement Techniques. *Silva Fennica* 40: (4) 577-588.
- Korhonen L., Korhonen K. T., Stenberg P., Maltamo M., Rautiainen M. (2007): Local Models for Forest Canopy Cover with Beta Regression. *Silva Fennica* 41: (4) 671-685.
- Lindner A. (2011): Small scale structure of forest stands in the Atlantic Rainforest – Notes on understorey light fluctuation. *Tropical Ecology* 52: (2) 139-150.
- Lin T., Rich P. M., Heisler D. A., Barnes F. J. (1992): Influences of canopy geometry on near-ground solar radiation and water balances of pinyon-juniper and ponderosa pine woodlands. *American Society for Photogrammetry and Remote Sensing 1992 Annual Meeting*. Albuquerque, NM. pp. 285-294.
- Lobell D. B., Asner G. P., Law B. E., Treuhaft R. N. (2001): Subpixel canopy cover estimation of coniferous forests in Oregon using SWIR imaging spectrometry. *Journal of Geophysical Research* 106: (D6) 5151-5160.

- Machado J.-L., Reich P. B. (1999): Evaluation of several measures of canopy openness as predictors of photosynthetic photon flux density in deeply shaded conifer-dominated forest understorey. *Canadian Journal of Forest Research* 29: 1438-1444.
- McCarthy B. C., Robison S. A. (2003): Canopy Openness, Understory Light Environments, and Oak Regeneration. U Sutherland E. K., Hutchinson T. F (ur.): Characteristics of mixed-oak forest ecosystems in southern Ohio prior to the reintroduction of fire. USDA Forest Service, Delaware, Ohio, 57-66.
- Mihók B., Gálhidy L., Kenderes K., Standovár T. (2007): Gap Regeneration Patterns in a Semi-natural Beech Forest Stand in Hungary. *Acta Silvatica et Lignaria Hungarica* 3: 31-45.
- Nascimento A. R. T., Fagg J. M. F., Fagg C. W. (2007): Canopy openness and LAI estimates in two seasonally deciduous forests on limestone outcrops in central Brazil using hemispherical photographs. *Revista Árvore* 31: (1) 167-176.
- Nikolić T., Kovačić S. (2008): *Flora Medvednice*. Školska knjiga, Zagreb.
- Oladi D. (2001): Developing A Forest Growth Monitoring Model Using Thematic Mapper Imagery. Session Code: **PS3-03** -- (Paper No. **271**) Proc. ACRS 2001 - 22nd Asian Conference on Remote Sensing, 5-9 November 2001, Singapore. Vol. **2**, pp. 1457-1462., <http://www.crisp.nus.edu.sg/~acrs2001/PS3.html>; pristupljeno 16.2.2011.
- Ostertag R. (1998): Belowground effects of canopy gaps in a tropical wet forest. *Ecology* 79: (4) 1294-1304.
- Payton I. J. (1988): Canopy closure, a factor in rata (*Metrosideros*) – kamahi (*Weinmannia*) forest dieback in Westland, New Zealand. *New Zealand Journal of Ecology* 11: 39-50.
- Pu R., Xu B., Gong P. (2003): Oakwood crown closure estimation by unmixing Landsat TM data. *International Journal of Remote Sensing* 24: (22) 4433-4445.
- Prasad P. R. C., Nagabhatla N., Reddy C. S., Gupta S., Rajan K. S., Raza S. H., Dutt C. B. S. (2010): Assessment forest canopy closure in a geospatial medium to address management concerns for tropical islands – Southeast Asia. *Environ Monit Assess* 160: 541-553.
- Rautiainen M., Stenberg P., Nilson T. (2005): Estimating Canopy Cover in Scots Pine Stands. *Silva Fennica* 39: (1) 137-142.
- Russo D., Cistrone L., Jones G. (2007): Emergence time in forest bats: the influence of canopy closure. *Acta Oecologica* 31: 119-126.
- Sang W., Chen S., Li G. (2008): Dynamics of leaf area index and canopy openness of three forest types in a warm temperate zone. *Frontiers of Forestry in China* 3: (4) 416-421.

- Santana O. A., Encinas J. I. (2011): Leaf area index and canopy openness estimation using high spatial resolution image quickbird. *Revista Caatinga* 24: (2) 59-66.
- Sasaki T., Imanishi J., Ioki K., Morimoto Y., Kitada K. (2008): Estimation of leaf area index and canopy openness in broad-leaved forest using an airborne laser scanner in comparison with high-resolution near-infrared digital photography. *Landscape and Ecological Engineering* 4: 47-55.
- Silbernagel J., Moeur M. (2001): Modeling canopy openness and understorey gap patterns based on image analysis and mapped tree data. *Forest Ecology and Management* 149: 217-233.
- Souza A. F., Martins F. R. (2005): Spatial variation and dynamics of flooding, canopy openness, and structure in a Neotropical swamp forest. *Plant Ecology* 180: 161-173.
- Stenberg P., Kangas T., Smolander H., Linder S. (1999): Shoot structure, canopy openness, and light interception in Norway spruce. *Plant, Cell and Environment* 22: 1133-1142.
- Stenberg P., Korhonen L., Rautiainen M. (2008): A relascope for measuring canopy cover. *Canadian Journal of Forest Research* 38: 2545-2550.
- Stephens S. L., Fry D. L., Franco-Vizcaíno E., Collins B. M., Moghaddas J. M. (2007): Coarse woody debris and canopy cover in an old-growth Jeffrey pine-mixed conifer forest from the Sierra San Pedro Martir, Mexico. *Forest Ecology and Management* 240: 87-95.
- Strasburger E., Noll F., Schenck H., Schimper A. F. W. (1988): *Udžbenik botanike za visoke škole: morfologija i fiziologija*. Školska knjiga, Zagreb.
- Tan C. P., Woodhouse I., Suarez J., Edwards C., Perks M. (2010): The Use of LIDAR Technology for Sustainable Forest Menagement in Glen Affric. 30th EARSel Symposium. Remote Sensing for Science, Education, and Natural and Cultural Heritage. UNESCO, Paris (France), 31 May - 3 June 2010. pp. 365-370., <http://www.earsel.org/?target=publications/proceedings/symposium-2010>; pristupljeno 16.2.2010.
- Van der Zande D., Stuckens J., Verstraeten W. W., Muys B., Coppin P. (2010): Assessment of Light Environment Variability in Broadleaved Forest Canopies Using Terrestrial Laser Scanning. *Remote Sensing* 2: 1564-1574.
- Vukelić J., Mikac S., Baričević D., Bakšić D., Rosavec R. (2008): *Šumska staništa i šumske zajednice u Hrvatskoj, Nacionalna ekološka mreža*. Državni zavod za zaštitu prirode, Zagreb.
- Vuković N., Nikolić T. (2010): *Medvednica*. U Nikolić T., Topić J., Vuković N. (ur.): *Botanički važna područja Hrvatske*. Školska knjiga, Zagreb, 271-278.

- Weiss M., Baret F., Smith G. J., Jonckheere I., Coppin P. (2003): Review of methods for in situ leaf area index (LAI) determination Part II. Estimation of LAI, errors and sampling. *Agricultural and Forest Meteorology* 121: 37-53.
- Xu B., Gong P., Pu R. (2003): Crown closure estimation of oak savannah in a dry season with Landsat TM imagery: comparison of various indices through correlation analysis. *International Journal of Remote Sensing* 24: (9) 1811-1822.
- Zeng Y., Schaepman M. E., Wu B., de Bruin S., Clevers J. G. P. W. (2008): Change detection of forest crown closure using an inverted geometric-optical model and scaling. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37: (B7) 1-6.